

## Metodologija psiholoških istraživanja

1

### obrada faktorijalni 1



### IV. Obrada podataka

#### B. Faktorijalni nacrti

##### 1. Jednofaktorski nacrti

- (a) organizacija podataka
- (b) deskriptivne statističke mere mere prebrojavanja  
mere centralne tendencije  
mere varijabilnosti
- (c) standardne mere
- (d) transformacije skupova mera

26. novembar 2018.

## B. Obrada faktorijalnih nacrti

2

- podsetimo se:
- obrada podataka za tri vrste nacrti:
  - **frekvencijski nacrti:**
    - 3 tipa: nacrti sa jednom, sa dve i sa tri varijable
  - **faktorijalni nacrti:**
    - 3 tipa: nacrti sa dve, sa tri i sa četiri varijable
  - **korelaciono-regresioni nacrti:**
    - 2 tipa: nacrti sa dve i sa tri varijable

### Faktorijalni nacrti

- nacrti sa kategoričkim NV i numeričkim ZV
- bavićemo se nacrtima sa:
  - 1, 2, i 3 NV (faktori)
  - 1 ZV

## B. Obrada faktorijalnih nacrti

3

### 1. Jednofaktorski nacrti (JFN)

- faktorijalni nacrti sa jednom NV (faktorom) i jednom ZV
  - broj nivoa faktora: dva (*bivalentan* faktor), tri (*trivalentan* faktor), četiri, itd
  - ponovljenost faktora (*nacrti*): mogu biti neponovljeni i ponovljeni
  - podaci: vrednosti NV i ZV za svaki objekt
  - deskriptivna statistika: proseci ZV za svaki nivo (kategoriju) faktora (NV)
  - statistika zaključivanja: postojanje stat. znač. razlika među prosecima
- **PRIMERI:** bivalentni faktori
  - neponovljeni nacrt: visine muškaraca i žena
    - faktor (NV): pol; nivoi faktora: muški pol, ženski pol
    - ZV: visina subjekata
    - istraživačko pitanje: da li postoji razlika u proseku visina dva pola?
  - ponovljeni nacrt: vreme reakcije na dve boje
    - faktor (NV): boja; nivoi faktora: crvena, zelena
    - ZV: vreme reakcije
    - istraživačko pitanje: da li postoji razlika u proseku vremena reakcije na boje?

## 1. Jednofaktorski nacrti (JFN)

4

### a. Organizacija podataka

- matrice podataka: dva tipa
- (1) matrica tipa objekti x varijable (OxV)
  - kao kod frekvencijskih nacrti
  - redovi: objekti; kolone: varijable
    - u JFN: dve kolone, za NV i za ZV
  - pogodno za neponovljene nacrti
    - npr. pol i visina
- (2) matrica tipa objekti x nivoi (OxN)
  - novi oblik matrica
  - redovi: objekti; kolone: nivoi NV (faktora)
    - ima onoliko kolona koliko NV ima nivoa
    - za bivalentni nacrt: dve kolone; za trival. nacrt: 3 kolone, ...
  - pogodno i za neponovljene i za ponovljene nacrti
    - npr. pol i visina; vreme reakcije na boje
- **važno:** programi za statističku obradu podataka obično 'očekuju' da u istom redu 'nađu' podatke koji se odnose na isti objekt, što znači:
  - **neponovljeni nacrti:** koristiti matrice OxV; **ponovljeni nacrti:** koristiti matrice OxN

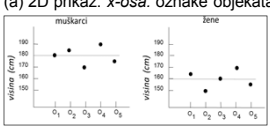
| #  | POL | VISINA |
|----|-----|--------|
| 1. | 1   | 180    |
| 2. | 1   | 185    |
| 3. | 1   | 170    |
| 4. | 1   | 190    |
| 5. | 1   | 175    |
| 6. | 2   | 165    |
| 7. | 2   | 150    |
| 8. | 2   | 160    |
| 9. | 2   | 170    |
| 10 | 2   | 155    |

| #  | muš | žene |
|----|-----|------|
| 1. | 180 | 165  |
| 2. | 185 | 150  |
| 3. | 170 | 160  |
| 4. | 190 | 170  |
| 5. | 175 | 155  |

## 1. Jednofaktorski nacrti (JFN)

5

- prikaz podataka
  - osim dva matricna prikaza podataka, u JFN koriste se i **grafički prikazi**
  - za razliku od frekvencijskih nacrti, kod kojih nismo razmatrali **grafičke prikaze podataka** već samo **rezultata** (frekvenci, procenta, proporcija)
- primeri grafičkih prikaza podataka
  - (a) 2D prikaz: x-osa: oznake objekata, y-osa: mere ZV
 



pojedinačni podaci:  
prikazani markerima  
(oznakama) objekata

proseci ZV:  
prikazani horizontalnim linijama

ovakav prikaz je pogodan samo u nekim slučajevima
  - (b) prikaz na brojnoj osi (x-osa): mere i markeri objekata
 



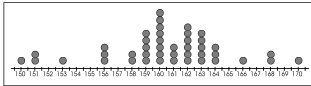
mana prikaza: za objekte sa istom merom markeri se preklapaju

ovakav prikaz uglavnom nije pogodan, ali se može popraviti

## 1. Jednofaktorski nacrti (JFN)

6

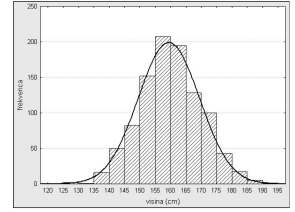
(c) popravljena, 2D varijanta prikaza (b)



markeri objekata sa istom merom ZV postavljaju se jedni iznad drugih, čineći markerske stubiće

visina stubića izražava frekvenciju mere

(d) histogram: korišćenje običnih stubića umesto markerskih



daleko najčešći način prikaza podataka mere ZV na x-osi su obično grupisane u intervale (razrede)

visina stubića (štipića) odgovara broju markera u prikazu (c), tj. markerskim stubićima

histogram prikazuje distribuciju (raspodelu) podataka

distribucija se često može aproksimirati normalnom (Gausovom) krivom

x-osa: mere ZV, y-osa: frekvencija

## 1. Jednofaktorski nacrti (JFN)

7

## b. Deskriptivne statističke mere: tri grupe mera

- mere prebrojavanja, mere centralne tendencije, mere varijabilnosti
- (1) **mere prebrojavanja**: odnose se na broj podataka u istraživanju
- zavisno od broja podataka na pojedinim nivoima faktora, nacrt može biti:
  - **balansiran**: ako je broj podataka jednak na svim nivoima
  - **nebalansiran**: ako je broj podataka različit na nekim nivoima
- **PRIMER**: istraživanje zavisnosti vremena reakcije od rukosti (dva nivoa)
  - nebalansiran nacrt: 10 levorukih i 100 desnorukih
    - problem: podaci na različitim nivoima nisu jednako pouzdani
  - balansiran nacrt: 100 levorukih i 100 desnorukih; 10 levorukih i 10 desnorukih
    - pogodniji za obradu i interpretaciju
- uočiti: faktorijalni i frekvencijski nacrti se **razlikuju** u tretiranju broja podataka
- **PRIMER**: *varijabla*: rukost; *kategorije*: levoruki i desnoruki
- **frekvencijski nacrt**: *cilj*: kolike su frekvence kategorija (lev. i des.) u uzorku
  - eksperimentator *ne* (želi da) kontroliše frekvence, već ih utvrđuje empirijski
- **faktorijalni nacrt**: *cilj*: kako ZV (vreme reakcije) zavisi od NV (rukosti)
  - eksperimentator *može* (i treba) da kontroliše frekvence (zbog balansiranja)
  - eksperimentator empirijski utvrđuje *proseke ZV* na različitim nivoima NV

## 1. Jednofaktorski nacrti (JFN)

8

## (2) mere centralne tendencije

- kada se utvrde vrednosti neke kvantitativne varijable dobijaju se:
  - (*individualne*) *mere*, (*individualne*) *opservacije*, *skalari*
  - sve ovakve mere uzete zajedno čine: *skup mera*, *varijablu*, *vektor*
- osnovna ideja mera centralne tendencije:
  - definisati jedan broj koji karakteriše ceo skup mera
  - taj jedan broj treba da bude *reprezentativan* odn. *tipičan* za ceo skup brojeva, da izražava *tendenciju* celog skupa, da bude neka vrsta *centra* tog skupa
- ova osnovna ideja se može *matematički* uobličiti na tri načina
  - naime, za meru centralne tendencije može se uzeti ili mera koja je u datom skupu *najčešća*, ili mera koja je *srednja*, ili mera koja je *prosečna*
- (1) **mod** (engleski: 'mode')
  - definicija: *najčešća* mera u datom skupu mera
  - **PRIMER**: kao primere za mere cent. tend. koristićemo dva mala skupa mera
    - prvi skup: {0, 1, 3, 3, 8}; za ovaj skup mod je 3 (jer trojki ima najviše)
    - drugi skup: {0, 1, 1, 3, 3, 8}; u ovom skupu postoje dva moda, 1 i 3
  - mod je jednostavna mera, ali se ne koristi često kao mera centralne tendencije, jer uglavnom nije mnogo informativna za skup

## 1. Jednofaktorski nacrti (JFN)

9

- (2) **medijana** (engleski: 'median')
- definicija: *srednja* mera u datom skupu mera
  - izračunavanje veličine medijane vrši se u dva koraka:
    - prvo se dati skup mera *poređa* u niz po veličini
    - zatim se traži broj koji je u tom nizu na *sredini* odn. u *centru*
  - budući da je medijana u centru, *jednak* broj mera je manji i veći od medijane
  - zavisno od toga da li u skupu ima neparan ili paran broj mera, medijana se različito računa
- **PRIMER**: ista dva skupa kao za mod
  - za skup {0, 1, 3, 3, 8} medijana je 3
    - kad je broj mera neparan, medijana je mera koja je tačno na sredini
    - u skupu ima 5 mera, a 3 je treća, srednja mera (dve su pre med. i dve posle)
  - za skup {0, 1, 1, 3, 3, 8} medijana je 2
    - u skupu ima paran broj mera (6), pa ne postoji jedinstvena srednja mera, već dve, a to su 1 (treća mera) i 3 (četvrta mera)
    - medijana se računa kao *prosek* dve srednje mere:  $(1+3)/2 = 2$ 
      - u skupu su tri mere pre medijane (0, 1, 1), a tri su posle (3, 3, 8)
- medijana se koristi znatno češće od moda, ali znatno ređe nego prosek

## 1. Jednofaktorski nacrti (JFN)

10

- (3) **aritmetička sredina (prosek)** (engleski: '(arithmetic) mean')
- definicija: *prosečna* mera u datom skupu mera
  - u matematici postoje i srodne ali drugačije mere, *geometrijska sredina* i *harmonijska sredina*, ali se one ne koriste mnogo u statistici
  - prosek skupa mera označava se često sa *M* (od 'mean')
  - *individualne mere* datog skupa mera označavamo sa *Y*, a njihov zbir sa  $\Sigma Y$
- izračunavanje proseka skupa mera vrši se u tri koraka:
  1. *saberu* se individualne mere, i dobije se njihov zbir:  $\Sigma Y$
  2. *prebroje* se individualne mere, i dobije se njihov broj: *N*
  3. dobijeni zbir se *podeli* sa dobijenim brojem:  $M = \Sigma Y / N$
- **PRIMER**: ista dva skupa, {0, 1, 3, 3, 8} i {0, 1, 1, 3, 3, 8}
  - prvi skup: zbir:  $\Sigma Y = 0+1+3+3+8=15$ ; broj:  $N=5$ ; prosek:  $M = \Sigma Y / N = 15/5 = 3$
  - drugi skup: zbir:  $\Sigma Y = 0+1+1+3+3+8=16$ ; broj:  $N=6$ ; prosek:  $M = \Sigma Y / N = 16/6 = 2.666\dots$
- korisno je utvrditi i *devijacije* (odstupanja) individualnih mera od proseka
  - oznaka: *d*; račun: prema tzv. *devijacionoj jednačini*:  $d = Y - M$
  - za prvi skup mera, {0, 1, 3, 3, 8}, skup devijacija od proseka 3 je {-3, -2, 0, 0, 5}
    - naime:  $-3 = 0-3$ ,  $-2 = 1-3$ ,  $0 = 3-3$ ,  $0 = 3-3$ ,  $5 = 8-3$
  - za drugi skup mera, {0, 1, 1, 3, 3, 8}, skup dev. je {-2.67, -1.67, -1.67, 0.33, 0.33, 5.33}
  - uočiti: zbir devijacija je nula (i mora da bude nula!)

## 1. Jednofaktorski nacrti (JFN)

11

- veoma odstupajuće mere od proseka se zovu *autlajeri* (engleski: 'outlier')
  - mogući srpski termini: 'izuzetak', 'štrčak', 'iznimak'
- ovakve mere mogu odražavati *stvarnu* raznolikost podataka date varijable, ali mogu i *nepripadati* ispitivanoj populaciji, ili čak biti *greške* u zapisu
- veličina *moda* i *medijane* obično ne zavisi mnogo od veoma odstupajućih mera, ali veličina *proseka* može znatno da zavisi od njih
- **PRIMER**: poredimo mere centr. tendencije skupa {0, 1, 3, 3, 8} i {0, 1, 3, 3, 8, 8}
  - *mod*: i za prvi i za drugi skup mod je 3
  - *medijana*: i za prvi i za drugi skup medijana je 3
  - *prosek*: za prvi skup prosek je 3, a za drugi skup prosek je 19!
- kaže se: prosek je manje *robustna* mera od moda i medijane
  - naime: prosek je manje *otporan* na autlajere, više se *menja* nego mod i medijana
- robustnost proseka zavisi od *veličine* datog skupa
  - što je skup veći, uticaj veličine pojedinačnih mera na prosek je manji
- mada se prosek najviše koristi, za neke skupove medijana je pogodnija
  - **PRIMER**: prosek i medijana dužine studiranja; visine primanja
    - postoji veoma mali broj studenata koji studiraju veoma dugo, i stoga 'veštački' podižu prosek dužine studiranja, ali ne utiču mnogo na medijanu

## 1. Jednofaktorski nacrti (JFN)

12

- u JFN postoje dve vrste proseka, *grupni* i *opšti*
- **PRIMER**: visine muškaraca (grupa 1) i žena (grupa 2)
- **grupni proseci**: proseci mera *pojedinih nivoa* (odn. grupa)
 

| #  | muš. | žena |
|----|------|------|
| 1. | 180  | 165  |
| 2. | 185  | 150  |
| 3. | 170  | 160  |
| 4. | 190  | 170  |
| 5. | 175  | 155  |

  - podaci za grupu 1 (muškarci): {180, 185, 170, 190, 175}
    - *oznake*: individ. mere:  $Y_1$ ; broj mera:  $N_1$ ; prosek:  $M_1$
    - račun:  $\Sigma Y_1 = 180 + \dots + 175 = 900$ ;  $N_1 = 5$ ;  $M_1 = \Sigma Y_1 / N_1 = 900/5 = 180$
  - podaci za grupu 2 (žene): {165, 150, 160, 170, 155}
    - *oznake*: individualne mere:  $Y_2$ ; broj mera:  $N_2$ ; prosek:  $M_2$
    - račun:  $\Sigma Y_2 = 165 + \dots + 155 = 800$ ;  $N_2 = 5$ ;  $M_2 = \Sigma Y_2 / N_2 = 800/5 = 160$
- kada je nacrt *balansiran*, tj.  $N_1 = N_2$ , često se oba broja označavaju sa *N*
- **opšti (totalni) prosek**: prosek mera *celog uzorka*
  - oznake: individualne mere:  $Y$ ; broj mera:  $N_1 + N_2 = N + N = 2N$ ; prosek:  $M_y$
  - podaci za obe grupe, tj. sve članove uzorka: {180, 185, ..., 170, 155}
    - važi:  $\Sigma Y = \Sigma Y_1 + \Sigma Y_2 = 1700$ ;  $2N = 10$ ;  $M_y = \Sigma Y / 2N = 1700/10 = 170$
- u *balansiranim* nacrtima, opšti prosek je *prosek grupnih proseka*, tj. njihova sredina:
  - $M_y = (M_1 + M_2) / 2 = (180 + 160) / 2 = 170$
- u *nebalansiranim* nacrtima, to ne mora biti slučaj, npr. opšti prosek vremena reakcija 10 levorukih i 100 desnorukih je mnogo bliži proseku desnorukih nego levorukih

### 1. Jednofaktorski nacrti (JFN) 13

- u JFN postoje dve vrste devijacije, *grupne* i *opšte (totalne)*
- PRIMER:** visine muškaraca (grupa 1) i žena (grupa 2)
- grupne devijacije:** odstupanja individualnih mera od proseka *svojih grupa*
  - grupa 1 (muškarci):  $d1 = Y1 - M1$ 
    - mere: {180, 185, 170, 190, 175},  $M1=180$
    - devijacije od 180: {0, +5, -10, +10, -5}
    - uočimo:  $\sum d1 = 0 + (+5) + (-10) + (+10) + (-5) = 0$
  - grupa 2 (žene):  $d2 = Y2 - M2$ 
    - mere {165, 150, 160, 170, 155},  $M2=160$
    - devijacije od  $M2=160$ : {+5, -10, 0, +10, -5}
    - uočimo:  $\sum d2 = +5 + (-10) + (0) + (+10) + (-5) = 0$  (pa je i prosek 0)
- opšte (totalne) devijacije:** odstupanja ind. mera od proseka *celog uzorka*
  - $dy = Y - My$
  - mere: {180, 185, 170, 190, 175, 165, 150, 160, 170, 155},  $My=170$
  - devijacije od  $My=170$ : {+10, +15, 0, +20, +5, -5, -20, -10, 0, -15}
  - uočimo:  $\sum dy = 10 + 15 + \dots -15 = 0$
- napomena: ako nije važna razlika između grupnih i opštih devijacija, sve devijacije označavamo sa  $d$ , individualne mere sa  $Y$ , a proseke sa  $M$ , prema formuli  $d = Y - M$

| #  | muš. | žene |
|----|------|------|
| 1. | 180  | 165  |
| 2. | 185  | 150  |
| 3. | 170  | 160  |
| 4. | 190  | 170  |
| 5. | 175  | 155  |
| M  | 180  | 160  |

### 1. Jednofaktorski nacrti (JFN) 14

- uočimo: bilo da su grupne ili opšte, pojedinačne devijacije mogu biti:
  - pozitivne ( $d>0$ ): to je slučaj ako je individualna mera *veća* od proseka ( $Y>M$ )
  - negativne ( $d<0$ ): to je slučaj ako je individualna mera *manja* od proseka ( $Y<M$ )
  - nulte ( $d=0$ ): to je slučaj ako je individualna mera *jednaka* proseku ( $Y=M$ )
- numerički i grafički prikaz podataka, proseka i devijacija

| #  | muš. dev. | žene dev. |
|----|-----------|-----------|
| 1. | 0         | +5        |
| 2. | +5        | -10       |
| 3. | -10       | 0         |
| 4. | +10       | +10       |
| 5. | -5        | -5        |
| M  | 0         | 0         |

- pojedinačni podaci  $Y1$  i  $Y2$ : prikazani *markerima* (oznakama) na dijagramima
- proseci  $M1$  i  $M2$ : prikazani *horizontalnim* linijama na visini proseka ("linije proseka")
- devijacije  $d1$  i  $d2$ : prikazane *odstojanjima* markera od linija proseka
  - $Y>M$ ,  $d>0$ : marker iznad linije;  $Y<M$ ,  $d<0$ : marker ispod linije;  $Y=M$ ,  $d=0$ : marker na liniji
- linije proseka imaju osobinu da su *centralne*, tj. da prolaze *sredinom* skupa markera
  - linije su *centralne*: u smislu da je *zbir* odstojanja markera *iznad* linija proseka jednak *zbiru* odstojanja markera *ispod* linija proseka
  - ova osobina sledi iz činjenice da je zbir svih devijacija nula

### 1. Jednofaktorski nacrti (JFN) 15

- strukturalna jednačina**
  - iz *devijacione jednačine* (koja glasi, prema definiciji devijacije):  $d = Y - M$
  - sledi *strukturalna jednačina*:  $Y = M + d$ 
    - PRIMER:**  $Y = 190$ ,  $M = 180$ ,  $d = 10$
    - devijaciona jednačina:  $d = Y - M$  odnosno  $10 = 190 - 180$
    - strukturalna jednačina:  $Y = M + d$  odnosno  $190 = 180 + 10$
- strukturalna jednačina prikazuje *strukturu* individualnih mera
  - individualna mera  $Y$  se sastoji od dve komponente,  $M$  i  $d$ :
    - prva komponenta, prosek  $M$ , je *zajednička* svim merama u skupu
    - druga komponenta, devijacija  $d$ , je *specifična* za svaku pojed. meru u skupu
- jedna interpretacija proseka i devijacija
  - proseci se, naročito u tehnici i prirodnim naukama, koriste prilikom obrade podataka *višestrukih merenja* iste pojave (na pr. položaja neke zvezde na nebu)
  - usled neminovnih grešaka prilikom merenja, pojedinačne mere se *razlikuju* jedne od drugih, a prosek daje *pouzdaniju* meru od svih pojedinačnih mera
  - u takvim situacijama, prosek skupa,  $M$ , se može smatrati kao najbolja *pretpostavka (teorija, model)* o stvarnoj meri neke pojave
    - stoga se proseci ponekad nazivaju *očekivane mere*

### 1. Jednofaktorski nacrti (JFN) 16

- pojedinačne mere,  $Y$ , odstupaju od modela, tj. proseka  $M$ , usled dejstva raznih nesistematskih spoljnih varijabli
- sa ovakve tačke gledišta, devijacije,  $d$ , odražavaju *nesavršenost* modela, njegov neuspeh da potpuno tačno predvidi pojedinačna merenja
- strukturalna jednačina  $Y = M + d$  se može opisno i metafizički izraziti na više načina:
  - podatak = model + odstupanje*
  - dato merenje = tačna mera + greška merenja*
  - činjenica = očekivanje + iznenađenje*
  - pojedinačno = opšte + posebno*
  - ...
- usled ovakvih razmatranja, odstupanja se često nazivaju *greške* (engleski: 'error')
  - međutim, ukažimo da je, iako odomačen u statistici, termin 'greška' većinom neprikladan
  - na pr., u slučaju merenja visine, nikako nije tačno da svi subjekti stvarni imaju istu visinu, a da su odstupanja pojedinih subjekata samo greške nastale usled nesavršenosti merenja
- napomena: postoji formalna *sličnost* mera u JFN i UFN:
 

|     |                               |                                   |   |   |
|-----|-------------------------------|-----------------------------------|---|---|
| JFN | skup opservir. mera: $Y$      | zbir mera: $\sum Y$               | prosek mera: $M = \sum Y / N$             | devijacije mera: $d = Y - M$ (važi: $\sum d = 0$ )          |
| UFN | skup opserv. frekvencija: $f$ | totalna frekvencija: $N = \sum f$ | očekivana frekvencija: $f^* = \sum f / k$ | rezidualne frekvencije: $d = f - f^*$ (važi: $\sum d = 0$ ) |
- razlika:** u JFN postoje *dve grupe* mera (dva nivoa), pa postoje  $Y1$  i  $Y2$ ,  $M1$  i  $M2$ , itd

### 1. Jednofaktorski nacrti (JFN) 17

- (3) mere varijabilnosti**
- u skupu mera neke varijable neće skoro nikad sve mere biti iste veličine
  - skoro uvek će postojati razlike tj. *varijabilnost (dispersija, raspršenost)* mera
  - varijabilnost je važan aspekt skupa mera, pored proseka
  - dva skupa mogu imati iste proseke ali različitu varijabilnost, i time se razlikovati
  - PRIMERI:** *proseci su jednaki a varijabilnosti različite*
    - varijabilnost količine leka u pilulama dve kompanije
    - varijabilnost plata u različitim zemljama
- osnovna ideja mera varijabilnosti je da se definiše:
  - jedna* mera koja karakteriše stepen *variranja* mera u okviru celog *skupa* mera
- kako definisati i konstruisati takvu meru, kako naći prikladnu formulu?
  - ključna osobina takve mere je da bude *proporcionalna* varijabilnosti, tj.:
    - da bude što *veći* broj što je varijabilnost skupa mera oko proseka veća
    - da bude *nula* ako u skupu mera nema varijabilnosti (tj. ako su sve mere iste)
    - da ne može da bude *negativna*
- postoji *više načina* da se *matematički uoblič* ova osnovna ideja
  - stoga postoji ne jedna nego *veći broj* mera varijabilnosti, a razmotrićemo šest

### 1. Jednofaktorski nacrti (JFN) 18

**(1) Raspon:  $R = Y_{max} - Y_{min}$**

- razlika između najveće mere ( $Y_{max}$ ) i najmanje mere ( $Y_{min}$ ) u skupu
- PRIMERI:**
  - vreme reakcije na crvenu i zelenu boju:
    - proseci:  $M_{crv} = 200$  ms,  $M_{zel} = 200$  ms
    - varijabilnost:
      - crvena:  $R = Y_{max} - Y_{min} = 250$  ms - 150 ms = 100 ms
      - zelena:  $R = Y_{max} - Y_{min} = 210$  ms - 190 ms = 20 ms
    - uočiti: proseci dve grupe su jednaki, a varijabilnosti su različite
  - visine muškaraca i žena
    - proseci:  $M = 180$  cm,  $M2 = 160$  cm
    - varijabilnost:
      - muškarci:  $R = Y_{max} - Y_{min} = 190 - 170 = 20$  cm
      - žene:  $R = Y_{max} - Y_{min} = 170 - 150 = 20$  cm
    - uočiti: proseci dve grupe su različiti, a varijabilnosti su jednake
- raspon je korisna i intuitivno jasna mera varijabilnosti
  - međutim, raspon ne uzima u obzir *sve* mere u skupu, već samo *dve* (najveću i najmanju)
  - postoje bolje mere varijabilnosti, koje uzimaju u obzir *sve* mere u skupu

### 1. Jednofaktorski nacrti (JFN) 19

- (2) **Prosečno odstupanje:**  $PO = \sum d / N$ 
  - formula je konstruisana po analogiji sa formulom za prosek:  $M = \sum Y / N$ 
    - kao što je M karakteristična *mera*, tako bi PO bilo karakteristično *odstupanje*
  - veliki problem:** PO je *uvek nula*, jer je zbir  $\sum d = 0$ , pa je i prosek  $\sum d / N$  nula
  - PRIMER:** devijacije visina kod muškaraca su +5, 0, -10, +10, -5, sa zbirom 0
  - zaključak:** PO je *beskorisna* kao mera varijabilnosti, i zato se i ne koristi
- (3) **Prosečno apsolutno odstupanje:**  $PAO = \sum |d| / N = \sum |Y-M| / N$ 
  - PRIMER:** apsolutne devijacije visina kod muškaraca su: 5, 0, 10, 10, 5, zbir = 30
    - $PAO = \sum |d| / N = 30 / 5 = 6$  cm
  - PAO odražava prosečnu devijaciju, ali bez obzira na *smernost* odstupanja (tj. da li su mere manje ili veće od proseka)
  - PAO ima upravo one osobine koje se traže za meru varijabilnosti:
    - PAO će biti veća što su devijacije veće (po apsolutnoj vrednosti), tj. ukoliko je varijabilnost mera oko proseka veća
    - PAO može biti nula samo ako su sve devijacije nulte
      - tada su sve mere jednake proseku, odn. međusobno, pa ni nema varijabilnosti
    - PAO ne može biti negativno, jer se zasniva na apsolutnim vrednostima
    - zaključak: za razliku od PO, PAO je *korisna* mera varijabilnosti
  - problem: PAO ima izvesne statističke mane, pa su druge mere pogodnije

### 1. Jednofaktorski nacrti (JFN) 20

- (4) **Varijansa:**  $V = \sum d^2 / N = \sum (Y-M)^2 / N$ 
  - PRIMER:** kvadrati devijacija visina kod mušk. su: 25, 0, 100, 100, 25, zbir = 250
    - $V = \sum d^2 / N = 250 / 5 = 50$
  - slično kao što je PAO prosečno *apsolutno* odstupanje, varijansa je prosečno *kvadrirano* odstupanje (PKO)
  - kvadriranje je statistički pogodnija operacija od apsolutne vrednosti
  - kao i PAO, varijansa ima sledeće tri povoljne osobine za meru varijabilnosti:
    - utoliko je veća ukoliko su devijacije veće (bez obzira na predznak)
    - nulta* je ako u podacima nema nema varijabilnosti
    - ne može biti *negativna*, jer kvadrati ne mogu biti negativni
  - problem: varijansa je, usled kvadriranja, intuitivno manje jasna mera nego PAO
- (5) **Zbir kvadrata:**  $SS = \sum d^2 = \sum (Y-M)^2$  (engl.: 'Sum of Squares')
  - PRIMER:** kvadrati devijacija visina kod muškaraca su: 25, 0, 100, 100, 25
    - $SS = \sum d^2 = 250$
  - SS, budući da je brojilac varijanse, ima slične tri osobine, naime:
    - utoliko je veći ukoliko su devijacije veće (bez obzira na predznak)
    - nulti je ako u podacima nema varijabilnosti; ne može biti negativan
  - kao što ćemo videti, SS se u nekim primenama koristi kao mera varijabilnosti
  - varijansa je pogodnija mera utoliko što odražava *prosek d<sup>2</sup>* (usled deljenja sa N)

### 1. Jednofaktorski nacrti (JFN) 21

- (6) **Standardna devijacija:**  $SD = \sqrt{V} = \sqrt{(\sum d^2 / N)} = \sqrt{(\sum (Y-M)^2 / N)}$ 
  - PRIMER:** visine kod muškaraca
    - $SD = \sqrt{V} = \sqrt{50} = 7.1$
  - SD ima slične tri povoljne osobine kao PAO, V, i SS:
    - utoliko je veća ukoliko su devijacije veće (bez obzira na predznak)
    - nulta* je ako u podacima nema varijabilnosti
    - ne može biti negativna
  - SD je u izvesnom smislu primerenija i smislenija mera nego V
    - naime, usled korenovanja, SD se (kao i PAO), izražava istim *jedinicama* kao individualne mere, a ne njihovim kvadratima
      - PRIMER:** u primeru sa visinama,  $SD = 7.1$  cm, dok je  $V = 50$  cm<sup>2</sup>
  - SD ima i neke matematički pogodne osobine, vezane za normalnu krivu
  - SD je najčešće korišćena mera varijabilnosti
  - odnos SD i PAO:
    - matematički su različite; u primeru, PAO = 6 cm, SD = 7.1 cm
    - SD je manje intuitivna od PAO, usled veće matematičke složenosti
    - PAO i SD su ipak slične, utoliko što obe izražavaju *tipičnu* devijaciju
      - kod PAO ta devijacija je *prosečna*, kod SD je *standardna*

### 1. Jednofaktorski nacrti (JFN) 22

poređenje mera varijabilnosti grupa u dva istraživanja

*visine muškaraca i žena*      *vreme reakcije na boje*

| #  | muš. devijacije |      | žene devijacije |      | #  | crv. devijacije |      | zel. devijacije |      |
|----|-----------------|------|-----------------|------|----|-----------------|------|-----------------|------|
|    | muš.            | žene | muš.            | žene |    | crv.            | zel. | crv.            | zel. |
| 1. | 180             | 165  | 0               | +5   | 1. | 200             | 195  | 0               | -5   |
| 2. | 185             | 150  | +5              | -10  | 2. | 150             | 200  | -50             | 0    |
| 3. | 170             | 160  | -10             | 0    | 3. | 250             | 205  | +50             | +5   |
| 4. | 190             | 170  | +10             | +10  | 4. | 220             | 190  | 20              | -10  |
| 5. | 175             | 155  | -5              | -5   | 5. | 180             | 210  | -20             | +10  |
| M  | 180             | 160  | 0               | 0    | M  | 200             | 200  | 0               | 0    |

| naziv  | formula                 | muš. | žene | crv.  | zel. |
|--------|-------------------------|------|------|-------|------|
| Raspon | $Y_{max} - Y_{min}$     | 20   | 20   | 100   | 20   |
| PO     | $\sum d / N$            | 0    | 0    | 0     | 0    |
| PAO    | $\sum  d  / N$          | 6    | 6    | 28    | 6    |
| V      | $\sum d^2 / N$          | 50   | 50   | 5800  | 250  |
| SS     | $\sum d^2$              | 250  | 250  | 29000 | 1250 |
| SD     | $\sqrt{(\sum d^2 / N)}$ | 7.1  | 7.1  | 34.1  | 7.1  |

učiti: sve mere, osim raspona, zasnovane su na devijacijama d od proseka

prema svim merama: varijabilnost u obe grupe je jednaka (jer su devijacije u obe grupe iste)

prema svim merama (osim PO): veća je varijabilnost u prvoj grupi

### 1. Jednofaktorski nacrti (JFN) 23

- mere centralne tendencije i varijabilnosti mogu se odnositi:
  - na *uzorak*, i tada se nazivaju *statistiki*, označeni sa M, SD, V itd
  - na *populaciju*, i tada se nazivaju *parametri*, označeni sa  $\mu$ ,  $\sigma$ ,  $\sigma^2$  itd
- vrednosti *statistika* se dobijaju empirijskim istraživanjima
- vrednosti *parametara* se *procenjuju* na osnovu vrednosti statistika
  - na pr., prosek populacije,  $\mu$ , se procenjuje prosekom uzorka, M
    - ako se na reprezentativnom uzorku muškaraca utvrdi prosek od 180 cm (statistik M), ta vrednost je najbolja moguća procena proseka visine u populaciji (parametar  $\mu$ )
- međutim, u slučaju stand. devijacije i varijanse, situacija je komplikovanija
  - može se pokazati da su statistici SD i V tzv. *pristrasne* procene parametara  $\sigma$  i  $\sigma^2$ 
    - grubo rečeno, ovi statistici nisu *najbolje* moguće procene odgovarajućih parametara
- u statističkoj teoriji se dokazuje da se ovi parametri mogu *bolje* proceniti ako se u formulama za V i SD umesto izraza N koristi izraz N-1, tj ako se umesto da se koristi:
  - uzoračka* varijansa:  $V = \sum d^2 / N$ , i *uzoračka* stand. dev.:  $SD = \sqrt{\sum d^2 / N}$ , koriste tzv. *populaciona* varijansa:  $V = \sum d^2 / (N-1)$ , i *populaciona* st. dev.:  $SD = \sqrt{\sum d^2 / (N-1)}$
- izraz  $N - 1$  se odnosi na broj stepena slobode (df)
  - naime: u skupu od N mera postoji, u principu, N stepeni slobode
  - ali: ako znamo njihov *prosek*, jedan stepen slobode se izgubio, pa je  $df = N - 1$
  - za skup od N devijacija takođe važi  $df = N - 1$ , jer se devijacije moraju sabrati do 0

### 1. Jednofaktorski nacrti (JFN) 24

#### c. standardne mere

- kad utvrdimo neki skup mera i njihov prosek M, možemo izračunati za svaku *meru* Y njoj odgovarajuću *devijaciju* d
- devijacija neke mere pruža informaciju o *odstupanju* mere od proseka, i time o *odnosu* date mere prema ostalim merama u skupu
- kada imamo informaciju o tome kolika je *mera* Y:
  - znamo: vrednost varijable za dati objekt
  - ali: ne znamo *odnos* te vrednosti prema proseku i ostalim vrednostima u skupu
- PRIMERI:**
  - data nam je mera koja je broj poena studenta na testu, npr. 21
    - znamo koliki je uspeh, ali ne znamo da li je 21 dobar ili loš uspeh, tj. da li je veći ili manji od proseka
  - data nam je mera koja je visina neke ženske osobe, npr. 170cm
    - znamo samu visinu, ali ne znamo da li je 170 mala ili velika visina u poređenju sa prosečnom visinom žena
- kada imamo informaciju o tome kolika je *devijacija* d:
  - ne znamo: samu vrednost varijable za dati objekt
  - ali: znamo za koliko je ta vrednost veća ili manja od proseka svih mera u skupu

### 1. Jednofaktorski nacrti (JFN) 25

- PRIMERI:**
  - devijacija date mere od prosečnog broja poena na testu iznosi -3
    - ne znamo: sam broj poena
    - ali: znamo da je taj broj *manji* (za 3) od proseka, tj. uspeh je ispodprosečan
  - devijacija visine ženske osobe od prosečne visine iznosi +10cm
    - ne znamo: koliko je osoba zaista visoka
    - ali: znamo da je *viša* (za 10) od proseka, dakle, njena visina je *natprosečna*
- utvrđivanjem devijacije, veličina *date* mere se postavlja u *kontekst* svih drugih mera u skupu
  - naime, *data* mera Y se poredi sa *karakterističnom* merom skupa, tj. prosekom M
  - matematički, to poređenje se vrši računanjem za *koliko* data mera odstupa od proseka, tj. računanjem *razlike*:  $d = Y - M$
- sad se javlja sledeći problem: kada znamo devijaciju, još uvek ne znamo *odnos* te devijacije prema drugim devijacijama
  - PRIMERI:** da li je data devijacija, npr. -3 ili +10, velika ili mala devijacija, u poređenju sa drugim devijacijama?
    - da li je uspeh na testu čija devijacija iznosi -3 samo malo ili veoma slabiji od prosečnog uspeha?
    - da li je osoba sa visinom 170cm izrazito visoka ili neznatno viša od proseka?

### 1. Jednofaktorski nacrti (JFN) 26

- pitanje: kako postaviti *datu* devijaciju d u *kontekst* svih drugih devijacija?
- odgovor: poređenjem *date* devijacije d sa *karakterističnom devijacijom* za ceo skup, a to je *standardna devijacija SD*
- matematički, poređenje se vrši utvrđivanjem *koliko puta* je d veća ili manja od SD, računanjem *količnika*:  $z = d / SD$
- rezultat se naziva *standard(izova)na mera* ili *z-skor*, u oznaci **z**
  - veličina **z** stavlja *datu* devijaciju d u *kontekst* ostalih devijacija

**PRIMER:** *odnos veličina d i z*

| mere | devijacije | z-skorovi |
|------|------------|-----------|
| 1.   | 165        | +5        |
| 2.   | 150        | -10       |
| 3.   | 160        | 0         |
| 4.   | 170        | +10       |
| 5.   | 155        | -5        |
| M    | 160        | 0         |

| devijacije | z-skorovi |
|------------|-----------|
| d = SD     | z = 1     |
| d > SD     | z > 1     |
| d < SD     | z < 1     |

z = 1.41: data devijacija d=10 je 1.41 puta veća od SD=7.1  
z = 0.7: data devijacija d=5 iznosi 0.7 od SD=7.1

**predznak d i z**

| devijacije | z-skorovi |
|------------|-----------|
| d = 0      | z = 0     |
| d > 0      | z > 0     |
| d < 0      | z < 0     |

predznak od z govori o *smeru* razlike mere od proseka, na isti način kao i kod d

u ovom primeru: SD = 7.1

- uočimo: kao i d, i z-skorovi se moraju sabirati do nule
- (naime:  $\Sigma z = \Sigma d / SD = 0 / SD = 0$ )

### 1. Jednofaktorski nacrti (JFN) 27

- z-skorovi ( $z = d / SD$ ) se mogu računati za bilo koji skup mera, ali:
- ako mere imaju *normalnu distribuciju*, z-skorovi nose dodatnu informaciju
  - oni nam govore o *proporciji* odn. *procentu* mera koje se nalaze ispod, iznad, ili između nekih *specijalnih* z-skorova
- naime, ako su mere normalno distribuirane onda važi:
  - oko 68% (tj. oko 2/3) svih mera imaće z-skorove između  $z = -1$  i  $z = +1$ 
    - it: polovina (34%) između -1 i 0, i polovina (34%) između 0 i +1
    - naime, normalna kriva je simetrična
  - oko 95% svih mera imaće z-skorove između  $z = -2$  i  $z = +2$
  - oko 99.7% svih mera (dakle skoro sve) imaće z-skorove između  $z = -3$  i  $z = +3$ 
    - ove činjenice se dokazuju u statističkoj teoriji
- PRIMER:** ako je za visine žena  $M=160$  a  $SD=7$ , onda:
  - za visinu 167 važi da je  $d = +7$ , što znači da je  $z = d / SD = 7 / 7 = +1$
  - za visinu 153 važi da je  $d = -7$ , što znači da je  $z = d / SD = -7 / 7 = -1$
  - znamo da su visine približno normalno raspoređene u populaciji
  - zaključak: oko 2/3 svih žena imaće visine između 153 cm i 167 cm
  - oko 1/6 žena imaće visine preko 167 cm, a oko 1/6 visine manje od 153 cm
  - uočimo: ovo su veoma važni praktični zaključci za industriju odeće!

### 1. Jednofaktorski nacrti (JFN) 28

- odnos individualnih mera Y i z-skorova
  - setimo se: iz devijacione jednačine  $d = Y - M$ , izvodi se strukturna jednačina  $Y = M + d$
  - uočimo: iz jednačine za z-skorove  $z = d / SD$ , može se izvesti jednačina  $d = z * SD$
  - kombinacijom gornje dve jednačine dobijamo novu jednačinu:
    - $Y = M + d = M + z * SD$
- odavde sledi:
  - ako znamo *z-skorove* z nekog skupa mera, možemo, pomoću ove jednačine, na osnovu njih potpuno rekonstruisati i same te *mere* Y
    - uslov: poznati su nam prosek M i standardna devijacija SD skupa
- PRIMER:**
  - neka z-skor visine neke osobe iznosi  $z = +2$
  - neka je u datom skupu mera prosek visina  $M=160$ , a standardna devijacija  $SD=7$
  - kolika je visina te osobe Y?
  - rešenje:  $Y = M + z * SD = 160 + 2 * 7 = 174$  cm

### 1. Jednofaktorski nacrti (JFN) 29

neke osobine SD i z-skorova

- u skupu z-skorova, SD može da služi kao *merna jedinica*
  - npr., kaže se da je visina neke osobe za 1 SD viša, a visina druge osobe za 1.5 SD niža od proseka
  - to je slično kao kad se, u skupu nestandardizovanih mera, kaže da je visina neke osobe za 10 cm viša a druge za 15 cm niža od proseka (ako je SD = 10 cm)
- ali, za razliku od uobičajenih mernih jedinica (kao što su cm, kg, itd), čije su veličine *fiksirane*, SD je *fleksibilna*
  - naime, SD se *menja* u zavisnosti od varijabilnosti datog skupa mera!
  - npr., u jednom skupu biće SD = 10 cm, u drugom će biti SD = 5 cm, itd
- pomoću SD mogu se *porediti* devijacije istog objekta za različite varijable (npr. visina i težina) sa različitim mernim jedinicama
  - PRIMER:** za skup osoba je  $M_{vis}=180$ cm,  $SD_{vis}=5$ cm,  $M_{tež}=80$  kg,  $SD_{tež}=10$ kg
  - određena osoba iz tog skupa ima nadprosečnu visinu (190 cm) i težinu (100 kg)
  - kako *uporediti* njene devijacije po visini ( $d=10$  cm) i po težini ( $d=20$  kg)?
    - da li je osoba 'viša (od proseka) nego što je teža (od proseka)?
  - poređenje se vrši preko SD: u ovom slučaju, obe individualne devijacije d iznose po +2 SD, tj. ova osoba u *jednako* meri odstupa od proseka po visini i po težini

### 1. Jednofaktorski nacrti (JFN) 30

- standardizacijom *različite* varijable svodimo na iste *razmere*
  - to olakšava poređenja, slično kao računanje procenata kod frekvenci
  - PRIMER:** da li uspeh na studijama (varijabla Z) više zavisi od školskog uspeha (varijabla X) ili od uspeha na prijemnom ispitu (varijabla Y)?
    - problem: X i Y imaju različite mere i ne mogu se direktno uporediti
    - rešenje: obe varijable se pre analize standardizuju
- pregled nekih bitnih statističkih pojmova i njihovih odnosa

**vektori (skupovi brojeva)**      **skalari (pojedinačni brojevi koji karakterišu skup)**

individualni skorovi Y → prosek M

↓

devijacioni skorovi d → standardna devijacija SD

↓

standardni skorovi z

*napomena:* da bi se vizuelno lakše razlikovali vektori i skalari, u daljem tekstu će vektori biti prikazivani **masnim** slovima (**bold**), kao gore